

**SVEUČILIŠTE U ZAGREBU
ŠUMARSKI FAKULTET
ŠUMARSKI ODSJEK**

**PREDDIPLOMSKI STUDIJ
URBANO ŠUMARSTVO, ZAŠTITA PRIRODE I OKOLIŠA**

FRAN BONO CINDRIĆ

Primjena hiperspektralnih skenera u šumarstvu

ZAVRŠNI RAD

ZAGREB, RUJAN 2019.

Zavod:	Zavod za izmjeru i uređivanje šuma
Predmet:	Daljinska istraživanja i GIS zaštićenih i urbanih područja
Mentor:	Doc. dr. sc. Mario Ančić
Asistent – znanstveni novak:	
Student:	Fran Bono Cindrić
JMBAG	1100682248544
Akad. godina:	2018/19
Mjesto, datum obrane:	Zagreb, 27.09.2019.
Sadržaj rada:	Slika: 9 Tablica: 0 Navoda literature: 38
Sažetak:	Hiperspektralni senzori baziraju se na refleksiji svjetlosti s površine koju snimaju odnosno skeniraju. Takvi skeneri detektiraju i do nekoliko stotina uskih spektralnih linija unutar određenog dijela elektromagnetskog spektra. Unutar velike količine spektralnih informacija koje bilježe hiperspektralni skeneri, algoritmi za obradu slika mogu identificirati određeni tip objekta ili promjene okoliša ovisno o spektralnom potpisu. U ovom završnom radu prikazati će se vrste hiperspektralnih skenera, način rada i prikupljanja podataka kao i sama primjena u šumarstvu i istraživanju vegetacije.

	IZJAVA O IZVORNOSTI RADA	OB ŠF 05 07
		Revizija: 1
		Datum: 27.9.2019.

„Izjavljujem da je moj *završni rad* izvorni rezultat mogega rada te da se u izradi istoga nisam koristio drugim izvorima osim onih koji su u njemu navedeni“.

vlastoručni potpis

Fran Bono Cindrić

U Zagrebu, 27.09.2019.

Sadržaj

1.	Uvod	1
2.	Cilj	3
3.	Hiperspektralni senzori	4
3.1.	Podjela hiperspektralnih senzora prema metodama snimanja	6
3.2.	Podjela hiperspektralnih senzora prema platformama na kojima su postavljeni.....	7
3.2.1.	Zrakoplovni hiperspektralni senzori	7
3.2.2.	Svemirski hiperspektralni senzori	9
3.2.3.	Prijenosni terenski i laboratorijski spektrometri.....	10
4.	Primjena hiperspektralnih skenera.....	11
4.1.	Primjena hiperspektralnih skenera u šumarstvu	12
4.1.1.	Hiperspektralna istraživanja u šumarstvu Republike Hrvatske	14
5.	Zaključak	155
6.	Literatura.....	16

1. Uvod

Nakon naglog razvoja aerofotogrametrije i filmova za snimanja iz zraka za vojne potrebe u II. svjetskom ratu, od 60-tih godina 20 stoljeća provode se u europskim zemljama istraživanja primjene infracrvenih kolornih (ICK) aerosnimaka za ustanovljavanje oštećenosti šumske vegetacije. Tako su prva istraživanja i primjena infracrvenog kolor aerosnimaka s ciljem utvrđivanja oštećenosti jele na području Hrvatske provedena 1988 godine, a ICK film se pokazao izuzetno pogodnim za procjenu zdravstvenog stanja (Pernar 1994). Najčešća metoda upotrebe ICK snimki je vizualna interpretacija. Ravnopravna je terenskom načinu rada, ali mnogo učinkovitija s obzirom na brzinu i objektivnost (Pernar 1994).

Sa napretkom i unaprđivanjem tehnologije za vojnu industriju i u istraživačke svrhe razvijeni su brojni senzori, koji prikupljaju podatke sa Zemljine površine u prostranom i široko razmanutom spektralnom rasponu. Takve sustave nazivamo multispektralnim sustavima i još uvijek čine okosnicu optičkog sustava prikupljanja podataka.

Ranih 70-tih godina 20-tog stoljeća lansiran je prvi orbitalni satelit sa multispektralnim sensorima Landsat 1 (SAD), nakon čega je uslijedio razvoj drugih satelita poput SPOT (Francuska) (slika 1) i IRS (Indija) satelita.



Slika 1.: SPOT 7 satelitski senzor

(https://s3.amazonaws.com/content.satimagingcorp.com/media/cms_page_media/1414/spot-7.png)

Temeljno ograničenje navedenih multispektralnih senzora je prikupljanje podataka u nekoliko širokih (100-200 nm) spektralnih kanala, nepravilnog prostornog rasporeda (van der Meer i de Jong 2001). Zbog takvih karakteristika dolazi do uprosječivanja spektara i prekrivanja slabijih značaka jačima (Kumar i dr. 2001), što za rezultat ima smanjenje ili gubitak informacija pa ih je nemoguće izdvojiti.

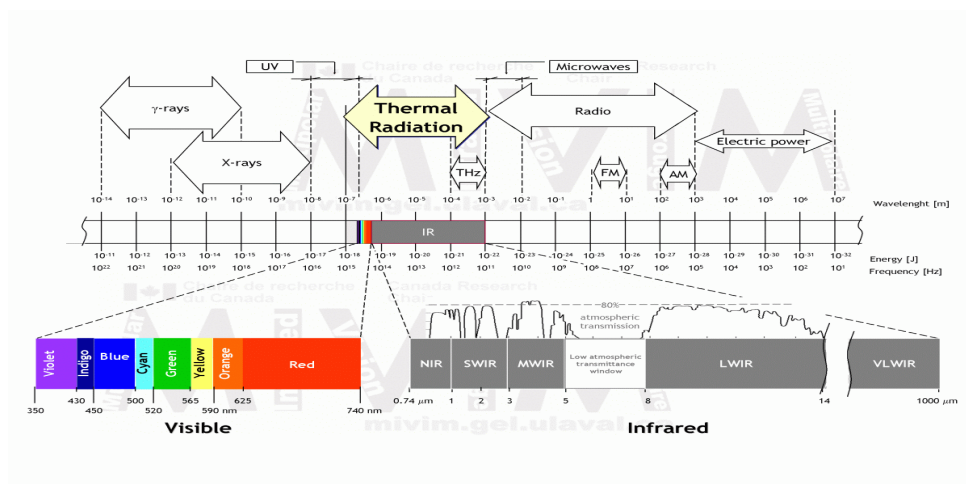
Nedostatak u prostornoj, spektralnoj i radiometrijskoj rezoluciji mnoge multispektralne senzore čini neadekvatnima za identificiranje objekata i njihovih značajki na Zemljinoj površini (Goetz 1995). Prepoznavanje nedostataka i razvoj tehnologije omogućio je razvoj novih senzora.

2. Cilj

Cilj završnog rada je prikazati vrste hiperspektralnih skenera, povijesni razvoj, način rada i prikupljanja podataka, prednosti i nedostatke u odnosu na prijašnje multispektralne senzore i metode prikupljanja podataka kao i samu primjenu u šumarstvu i istraživanju vegetacije.

3. Hiperspektralni senzori


Prepoznavanjem ograničenja multispektralnih senzora i sustava, razvijane su poboljšane tehnologije temeljene na spektroskopiji, prilikom čega je ograničeni broj kanala poboljšan primjenom niza uskih graničnih kanala (Aspinall i dr.). Ti kanali su se protezali od vidljivog sve do termalnog područja (slika 2).



Slika 2.: Prikaz elektromagnetskog spektra

(http://image.absoluteastronomy.com/images/encyclopediainages/i/in/infrared_spectrum.gif)


Hiperspektralni skeneri, za razliku od multispektralnih (slika 3), prilikom mjerenja bilježe određenu količinu „slika“ kao skup gdje svaka pojedina „slika“ unutar cijelog skupa predstavlja pojedini valni raspon unutar elektromagnetskog spektra. Također, hiperspektralni način snimanja koristi kontinuirane raspone valnih dok multispektralno snimanje koristi podskup ciljanih valnih duljina na odabranim mjestima. (Veys i dr. 2017).



Slika 3. Razlika između multispektralnih i hiperspektralnih podataka. (https://en.wikipedia.org/wiki/Hyperspectral_imaging)


Hiperspektralno snimanje obuhvaća postupak prikupljanja i obrađivanja reflektiranih podataka s ciljem dobivanja spektralne informacije iz svakog piksela na slici. Snimanje i prikupljanje reflektirajućeg zračenja različitih valnih duljina omogućuje nam otkrivanje i određivanje karakterističnih značajki predmeta i materijala od kojih je izgrađen.

Matrice spektralnih uzoraka grade se na osnovu snimljenih linija po sistemu linija po linija kako bi na taj način oblikovali dvodimenzionalnu sliku (x i y prostorne osi), dok treća z os prikazuje spektralne podatke za svaki snimljeni piksel (λ os). Takav prikaz nazivamo spektralnom kockom (slika 4).



Slika 4. Primjer spektralne kocke (<https://www.findlight.net/blog/2017/05/21/hyperspectral-imaging/>)

Prema Buckinghamu i dr. (2005), na hiperspektralnim snimkama, apsorpcija i raspršivanje čestica (reflektirajuće zračenje) formiraju karakteristične potpise (slika 5) i na taj način omogućavaju detekciju objekata.

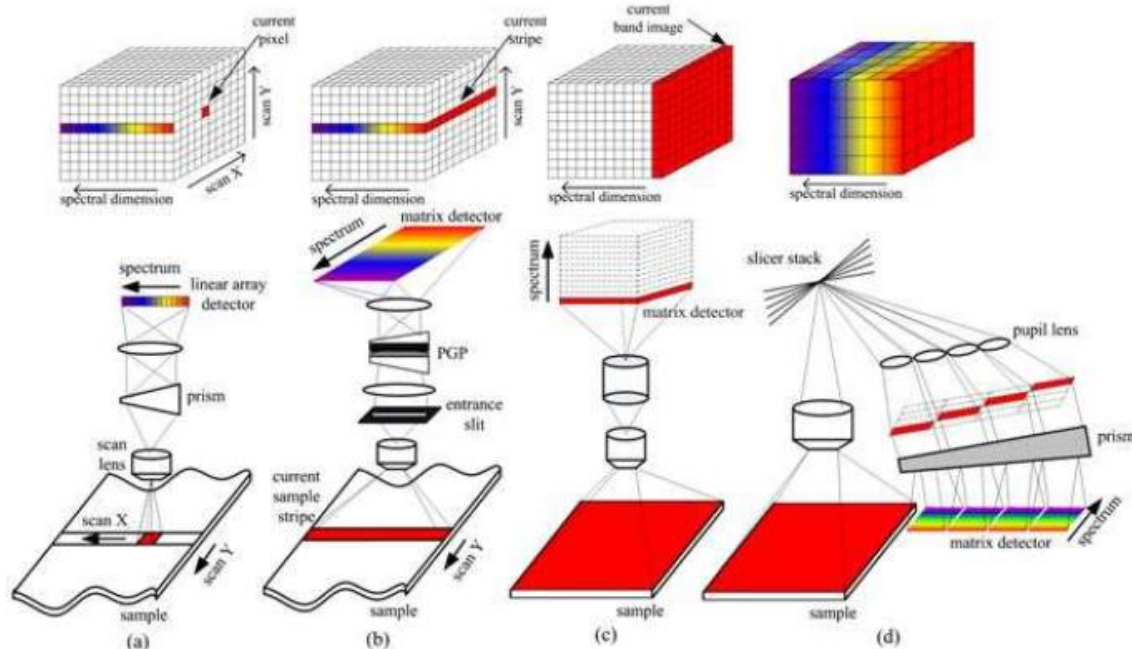


Slika 5. Prikaz spektralnih potpisa za tri spektralne uzorke vegetacije, kamena i sjene (Ančić 2011).

Hiperspektralne sustave možemo podijeliti prema metodama snimanja (*Whiskbroom*, *Pushbroom*, *The staring approach* i *Snapshot*) i prema nositeljima/platformama na kojima su postavljeni (satelitski, zrakoplovni, terenski/laboratorijski).

3.1. Podjela hiperspektralnih senzora prema metodama snimanja

Prema metodama koje se koriste za snimanje, senzore možemo podijeliti na (Li i dr. 2013) (slika 6) :



Slika 6. Podjela senzora prema metodama snimanja: a) „Whiskbroom“ metoda sa točkastim senzorom; b) „Pushbroom“ metoda sa linijskim senzorom; c) The staring approach metoda sa senzorom sa sekvencijalnim bilježenjem boja; d) Snapshot metoda sa površinskim senzorom (Li i dr. 2013).

- Točkasti senzori (engl. Whiskbroom) (slika 6a) su senzori koji snimaju u dva koraka - jedan u spektralnoj, a drugi u prostornoj domeni i često koriste rotirajuća ogledala koja usmjeravaju reflektiranu svjetlost na jednu ili nekoliko grupiranih detektorskih ćelija. Snima se točka po točka. Mehanizam za skeniranje potreban je za prikupljanje hiperspektralnih podataka preko površine objekta (Miljković, 2017). Reflektirano svjetlo se pomoću prizme raspršuje i registrira na linearnom detektoru. Prednosti toga

senzora su visoka rezolucija te jednostavni i jeftini detektori. Komplicirani mehanizam skeniranja jedan je od osnovnih nedostataka takvih senzora što može dovesti do velikih pogrešaka u geometriji prikaza i georeferenciranju. Nadalje, proces snimanja traje relativno dugo i nije moguće raditi brze snimke u nizu (Li i dr. 2013).


- Linijski senzori (engl. Pushbroom) (slika 6b), za razliku od točkastih koji snimaju točku po točku, simultano snimaju liniju prostornih podataka. Linijski skener može prikupiti više svjetla i značajno smanjuje vrijeme skeniranja u odnosu na točkasti skener te je jednostavniji za rukovanje. Nedostaci linijskog skenera prema Li i dr. 2013 su: rezolucija u smjeru linijskog senzora (ovisi o broju i veličini fotodetektora u senzoru) i nemogućnost snimanje objekata u kretanju (vrijeme skeniranja iznosi od nekoliko sekundi do nekoliko minuta).
- „The staring approach“ senzori (slika 6c), također poznati i kao senzori koji odvajaju pojedine kanale, primjenjuju metodu spektralnog snimanja čiji rezultat su 2D snimke s punom prostornom informacijom u jednom spektralnog kanalu. Za razliku od točkastog i linijskog skenera, cijela scena snimljena je odjednom u jednom spektralnog kanalu. Za različite valne duljine moguće je koristiti različite ekspozicije, a konačni broj spektralnih područja ovisi o korisniku (Li i dr. 2013).
- Površinski „Snapshot“ senzori (slika 6d) koriste tzv. „snapshot“ metodu snimanja koja istovremeno bilježi prostorne i spektralne informacije na površini detektora, što znači da bilježi kompletnu spektralnu kocku jednom snimkom. (Li i dr. 2013.)

3.2. Podjela hiperspektralnih senzora prema platformama na kojima su postavljeni

3.2.1. Zrakoplovni hiperspektralni senzori

Razvoj hiperspektralnih senzora započeo je u primjeni na zrakoplovima za geološke istraživačke svrhe. Komercijalno istraživanje minerala je bila prvotna namjena ovih hiperspektralnih senzora.

Zrakoplovne hiperspektralne snimke su dostupne od ranih 80-tih godina 20. st.. Njihov razvoj karakteriziraju mali namjenski senzori (Goetz 1995), a značajan napredak u hiperspektralnim istraživanjima započeo je predstavljanjem NASA AVIRIS (Airborne Visible/Infrared Imaging Spectrometer) 1983. godine (Vane i dr. 1993). Bio je to prvi senzor koji je skupljao slikovne podatke u uskim kanalima od vidljivog do kratkovalnog infracrvenog područja (slika 7).



Slika 7.: AVIRIS hiperspektralni senzor
(https://www.nasa.gov/images/content/612114main_AVIRIS_checkout.jpg)

Usporedno sa razvojem AVIRIS-a razvijane su i komercijalne inačice senzora poput CASI (Compact Airborne Spectrographic Imager) od strane ITRES-a ili HyMap-a od strane Integrated Spectronics Ltd.

Iako su hiperspektralna istraživanja podrazumijevala motrenja u području od vidljivog do kratkovalnog infracrvenog zračenja (400-2500 nm), mnogi senzori rade samo unutar jednog dijela tog područja poput CASI senzora (404-1050 nm). Senzori koji pokrivaju cijeli navedeni spektar su AVIRIS sa 224 kanala i HyMap sa 126 kanala. U novije vrijeme senzor DAIS sa 79 kanala pokriva i toplinsko infracrveno područje 3000-5000 nm i 8000-12600 nm (Ben-Dor i dr. 2002).

Udaljenost od najbližeg razlučivog objekta određuje prostornu razlučivost senzora kojim se obavlja snimanje. Prostorna razlučivost većinom je diktirana visinom leta

zrakoplova, pa je u ponekim slučajevima prilikom dobivanja tražene rezolucije potrebno promijeniti zrakoplovnu platformu (Vane i dr. 1993). Osim prostorne razlučivosti, visina leta zrakoplova određuje i opseg pokrivenosti. Što je visina veća, opseg pokrivenosti odnosno površina snimanja biti će veća i obrnuto.

S razvojem hiperspektralnih skenera dolazi do učestalijeg snimanja površina na kojima je teško primjetiti promjene. U određenim područjima, kao što su pustinje, promjene su neznatne i uočavaju se tek primjenom dužih vremenskih intervala (Lucas i dr. 2004). Vremenski intervali odnose se na učestalost (frekvenciju) promatranja određenog područja.

3.2.2. Svemirski hiperspektralni senzori

Svemirski hiperspektralni senzori omogućuju pokrivenost velikih površina, ponavljajuća opažanja u redovitim intervalima, te smanjenje izobličenja uzrokovano atmosferskih utjecajima i gibanjem platforme na koju su postavljeni (zrakoplovi, baloni, dronovi).

Prvi dostupni satelit u uporabi sa hiperspektralnim senzorom MODIS je bio EOS TERRA-1 1999 godine. Od 2002 godine lansirani su sateliti sa hiperspektralnim senzorima ASTER i MERIS. ASTER je imao hiperspektralna svojstva ali u odabranim područjima valnih duljina, odnosno centriran je na karakteristična apsorpcijska svojstva (npr. za svojstva ugljika) (Ellis 1999). MERIS senzor je za razliku od ASTERA u potpunosti bio programabilan za spektra od 390-1040 nm, snimao je u 15 kanala koje je bilo moguće odabrati prema potrebi.

Prvi hiperspektralni senzor koji prikupljao podatke kontinuirano po cijelom spektru od 400 do 2500 nm u 220 kanala bio je Hyperion, lansiran 2000. godine.

Iako je kontinuirani spektar koristan za razna istraživanja, za mnoge aplikacije je utvrđeno kako se tražena informacija teže izdvaja iz velikog broja skupljenih informacija u odnosu na izdvajanje iz manjeg broja specifičnih spektralnih kanala. U tom slučaju, izdvajanje i odabir značajki postaje sve važnija stavka pri odradi snimki (Lucas i dr. 2004).

Svemirski hiperspektralni senzori, u odnosu na zrakoplovne, imaju manju prostornu rezoluciju. Uzrok manje prostorne rezolucije je visina leta platforme. Senzori niske prostorne

rezolucije sa hiperspektralnim sposobnostima omogućuju multitempolarno globalno motrenje kroz duži vremenski period, te jednoobraznost u osvjetljenju i geometriji slike (van der Meer i dr. 2001)

Područje pokrivenosti prilikom snimanja ovisi o širini pojasa snimanja koji varira od senzora do senzora. Velika širina pojasa (MODIS 2330 km, MERIS 1150 km) omogućava skupljanje podataka na većoj površini u jednome prolazu, ali istovremeno ograničava njihovu upotrebu na lokalnoj razini ili za potrebe studija okoliša. Mogućnost snimanja područja u pravilnim vremenskim periodima korisno je za potrebe kartiranja i praćenja vegetacije, a snimljeni podaci formiraju arhive. Potencijalna dobrobit ovakvih arhiva je ogromna, posebno za mogućnosti razlikovanja vegetacijskih zajednica i za razumijevanje sezonskih varijabilnosti biofizičkih i biokemijskih svojstava (Lucas i dr. 2004)

3.2.3. Prijenosni terenski i laboratorijski spektrometri

Prikupljanje podataka satelitskim i zrakoplovnim hiperspektralnim sensorima ne možemo promatrati odvojeno od laboratorijskog i terenskog prikupljanja uzoraka jer predstavlja temelj razumijevanja prikupljenih podataka sa zrakoplovnih i satelitskih senzora i imaju važnu ulogu u kalibraciji zrakoplovnih i satelitskih snimki, zbog njihove varijabilnosti i različitih utjecaja prilikom snimanja (vremenski uvjeti i slično). Upravo je to razlog razvoja velikog broja spektrometara poput Milton, IRIS, i drugih.

Unaprijeđenjem tehnologije rezultiralo je povećanjem osjetljivosti senzora i smanjivanjem vremena skeniranja i omogućilo prikupljanje podataka visoke kvalitete. Takvom načinu prikupljanja podataka uvelike je pomogao razvoj računalne tehnologije što je omogućilo bržu obradu podataka.

Terenska i laboratorijska spektralna istraživanja imaju značajnu ulogu prilikom izrade spektralnih knjižica podataka koje kasnije mogu biti upotrebljene za razne namjene (Kruse i Hauff 1991, Kruse i dr. 1993.)

4. Primjena hiperspektralnih skenera

Hiperspektralni senzori su dugi niz godina od njihove pojave imali uporabu u vojne svrhe. Od trenutka kada je tehnologija postala dostupna u civilnom segmentu nalazimo je u raznim primjenama od zdravstva, obrade hrane, iskorištavanju mineralnih dobara, za potrebe sigurnosnih nadzora, u astronomiji, ekologiji, prostornom planiranju, šumarstvu, poljoprivredi, arheologiji i dr..


S obzirom na velike mogućnosti primjene hiperspektralnih podataka u proučavanju i zaštiti okoliša možemo ih koristiti u:

- kartiranju biljnih vrsta i staništa, posebno u osjetljivim područjima ugroženih vrsta (Ančić i dr. 2011.),
- izradi karata močvarnih zemljišta za udaljena područja od interesa (Ančić i dr. 2011.),
- unapređivanju kartiranja biljnih vrsta (Ančić i dr. 2011.),
- krčenju šuma i degradaciji šumskih površina (Ančić i dr. 2011.),
- identificiranju i nadzoru štetnih korova (Ančić i dr. 2011.),
- nadzoru biomase i paljenju biomase (Ančić i dr. 2011.),
- kartiranju invazivnih vrsta, veličini uzrokovane štete, te ublažavanje posljedica (Ančić i dr. 2011.),
- kartiranju napada štetnih kukaca u šumama (Ančić i dr. 2011.),
- kartiranju zdravstvenog stanja šuma (Ančić i dr. 2011.),
- nadgledanju oštećenja rudarenjem i rehabilitaciji uništenih područja (Ančić i dr. 2011.),
- taloženju industrijske prašine i čestica iz atmosfere (Ančić i dr. 2011.),
- detekciji zagađenja tla i vode ugljikovodicima vezanim uz industrijsku aktivnost i nadzor naftnih cjevovoda (Ančić i dr. 2011.),
- onečišćenju vode (Ančić i dr. 2011.),
- poljoprivredi za predviđanje i analizu usjeva, vrtlarstvo, upravljenje navodnjavanjem (Ančić i dr. 2011.).

Najveća prednost prilikom upotrebe hiperspektralne tehnologije očituje se u ranijoj detekciji problema i donošenju odluka zahvaljujući velikom broju raznovrsnih informacija što uvelike pomaže pri odabiru pravovremenih i konkretnih postupaka kojima se određeni problem može ublažiti ili u potpunosti spriječiti (ukloniti).

4.1. Primjena hiperspektralnih skenera u šumarstvu

Kako bi pobliže objasnili primjenu hiperspektralnih senzora u istraživanju vegetacije, a pri tome i njegovu primjenu u šumarstvu ključno je navesti opisne elemente spektralnih potpisa vegetacije poput *green peak*, *chlorophyll well*, *red edge* i *NIR plateau* (slika 8) (Kumar 1998). Poseban značaj ima *red edge* koji je definiran kao porast refleksije na granici između apsorpcije klorofila u crvenom dijelu i raspršivanja unutar lista u bližem infracrvenom dijelu spektra (Treitz i Howarth 1999), a nalazi se u području od 680 do 750 nm bez obzira na vrstu (Kumar i dr. 2001).



Slika 8. Karakteristična hiperspektralna krivulja za vegetaciju sa pojmovima koji je opisuju (https://www.mdpi.com/water/water-11-01368/article_deploy/html/images/water-11-01368-g004.png)

Hiperspektralno skeniranje u šumarstvu omogućava prikupljanje podataka o količini lisne mase, biomase ili pri određivanju vrsta u sastojini. Prema Skoupý i dr. (2011) hiperspektralne skenere je moguće koristiti prilikom određivanja vrsta u šumskim sastojinama i njihove starosti do 80% točnosti.

Postoje mnogi primjeri primjene hiperspektralnog snimanja za određivanje biokemijskih varijabli dušika i lignina, apsolutnog sadržaja vode u lišću biljke, mjerenje koncentracije pigmenta u listovima, u mjerenju sadržaja klorofila u biljkama i dr..

Klorofil vrlo učinkovito apsorbira vidljivu svjetlost, ali apsorbira plavu i crvenu valnu duljinu u jačem intenzitetu od zelene. Takav način refleksije zdrave biljke na spektralnim krivuljama očitavamo kao zelenu boju, odnosno dolazi do stvaranja karakterističnog „vrha“ refleksije unutar zelenog dijela vidljivog spektra (*Chlorophyll peak*). Smanjenjem vitalnosti dolazi do smanjenja apsorpcije klorofila što rezultira smanjenjem refleksije u crvenom i bližem infracrvenom području (NIR). Pomaci između ta dva područja najčešće ukazuju na stres stabala prikazan na lisnoj masi (Ferretti 1997).

Van Aardt i Wynne (2001) su dokazali kako pomoću infracrvenog dijela spektra i kratkovalnog infracrvenog područja (SWIR) izvornih hiperspektralnih podataka mogu prepoznati i determinirati četinjače i listače umjerenog područja.

Hiperspektralno skeniranje može uvelike pomoći i pri monitoringu invazivnih vrsta, naročito grmova koji se smatraju štetnima, a ometaju rast i razvoj autohtonih vrsta drveća. Prilikom motrenja određenog područja, moguće je utvrditi koridore i smjerove kojima su se invazivne vrste širile (slika 9).



Slika 9. Prikaz koridora invazivnih vrsta

(<https://www.techbriefs.com/component/content/article/tb/supplements/it/features/15361?start=1>)

Razni su razlozi pogoršanja zdravstvenog stanja šuma. Kukci, gljivične bolesti, onečišćenja tla, zagađenje zraka, suše, ekstremne vremenske prilike, antropogeni utjecaj i drugi čimbenici izazivaju stres u šumama. Stres u šumama pokazuje razne simptome od

kojih se neki mogu otkriti hiperspektralnim skeniranjem (Stone i dr. 2017). Povećana potražnja za zdravstvenom procjenom šuma i njenim stalnim monitoringom za opstanak biološke raznolikosti zahtjevala je uvođenje novih tehnologija u istraživanja poput multispektralnih i hiperspektralnih sustava. Hiperspektralni skeneri kao tehnologija koja prikuplja veliki broj podataka po jedinici površine pokazala se dobrim izvorom informacija u šumarstvu, pogotovo u proučavanju zdravstvenog stanja.

Za mjerenje zdravstvenog stanja vegetacije moguće je upotrebljavati različite indekse kao što su indeks vegetacije prilagođen zemljištu (eng. Soil Adjusted Vegetation Index - SAVI) ili modificirani indeks vegetacije (eng. Modified Soil Adjusted Vegetation Index – MSAVI) (Qi i dr. 1994).

4.1.1 Hiperspektralna istraživanja u šumarstvu Republike Hrvatske

Prva hiperspektralna istraživanja u Hrvatskoj započinju u sklopu programa Europske zajednice (ARC I SMART projekti) kada su provedena prva multispektralna i hiperspektralna snimanja na Medvednici. Rezultat su bile prve spektralne krivulje refleksije jele i imele (Pernar 1994).

U nastavku istraživanja izvršena su snimanja u kontroliranim uvjetima pomoću kojih su izdvojeni čisti spektralni potpisi (endmemberi) za jelu i imelu. Ti čisti spektralni potpisi su poslužili kao ulaz za daljnja istraživanja koja su provedena hiperspektralnim snimanjem na području UŠP Gospić (Ančić 2011).

Hiperspektralno snimanje provedeno 2010 godine na području UŠP Gospić polučilo je rezultat u kojem je prvi puta izdvojena vrsta unutar vrste, odnosno pomoću hiperspektralnih snimaka su razlučeni grmovi bijele imele unutar krošanja jele. Izdvojeni spektralni potpisi su postali dio baze podataka spektralne knjižnice koja može poslužiti u budućim istraživanjima (Ančić 2011, Ančić i dr 2014).

5. Zaključak

Napredovanjem tehnologije hiperspektralni skeneri se usavršavaju, a njihove snimke postaju dostupne velikom broju istraživača, te pronalaze primjenu u velikom broju znanstvenih disciplina.

Kako u drugim disciplinama, tako i u šumarstvu ovakav način snimanja možemo koristiti u različitim granama kao što su određivanje biomase, kartiranja šumskih vegetacija, monitoring zdravstvenog stanja, monitoringa progradacije kukaca, monitoringa širenja gljivičnih bolesti, mjerenja zaliha ugljika, mjerenja sadržaja klorofila u lišću, procjeni produktivnosti i dr..

U usporebi sa terenskim načinom istraživanja, količina povratnih informacija iz hiperspektralnih snimki je veća i ekonomski isplativija za potrebe šumarstva s obzirom na brzinu obavljanja poslova. No hiperspektralni skeneri ne mogu zamijeniti terenska istraživanja, već se trebaju, u sinergiji sa terenskim istraživanjima, nadopunjavati i pomagati pri donošenju bitnih odluka poput provođenja zaštitnih mjera, praćenja stanja ekosustava, i dr., te kao takve pridonijeti pravovremenom uočavanju negativnih posljedica na šume, šumske zajednice i šumske ekosustave.

Veliku efikasnost hiperspektralnih senzora možemo postići provođenjem kontinuiranih višegodišnjih praćenja vegetacije, a poznavanje varijabilnosti uzoraka je ključ za donošenje odluka.

Mogućnost primjene hiperspektralnih senzora za potrebe u svim granama šumarstva je velika, s obzirom na količinu informacija koju oni mogu isporučiti. Upravo zbog raznovrsnih mogućnosti hiperspektralnih senzora preporuka je uvesti ih u operativnu primjenu.

6. Literatura

- Ančić, M. 2011., Primjena multispektralnih i hiperspektralnih snimaka u procjeni oštećenosti obične jele (*Abies alba* Mill.) i detekciji imele (*Viscum album* L.ssp. *abietis*/Weisb./Abrom.), Zagreb
- Ančić M, Bajić M., Kolić J., Pernar R., Seletković A., 2014., Detecting mistletoe infestation on Silver fir using hyperspectral images, iForest (2014) 7: 85-91, Zagreb
- Aspinall R. J., Marcus A.W., Boardman J.W. 2003, Considerations in collecting, processing, and analysing high spatial resolution hyperspectral data for environmental investigations, Sjedinjene Američke Države
- Balazy R., Hycza T., Sterenczak K., 2018., Potential use of hyperspectral data to classify forests tree species, Varšava
- Ben-Dor E., Patkin K., Banin A., Karnieli A., 2002. Mapping of several soil properties using DAIS-7915 hyperspectral scanner data - A case study over soils in Israel, Izrael
- Bogdan W., Piotr W., 2005., Forest map revision using the hyperspectral scanners Asia Images, Varšava
- Buckingham R., Staenz K., 2014., (Review of current and planned civilian space hyperspectral sensors for EO, Kanada
- Gajski D., Miljković V., Vela E., 2017., Spatial Calibration of the Hyperspectral Line Scanner by the Bundle Block Adjusting Method Geodetski list, 2, 127-142, Zagreb
- Goetz A., 1995., Three decades of hyperspectral remote sensing of the Earth: A personal view, Sjedinjene Američke Države
- King D.J., 2000., Airborne remote sensing in forestry: Sensors, analysis and applications, The Forestry Chronicle, 76, 859-876, Francuska
- Koch B., 2016., Remote sensing supporting national forest assessments, Faculty of Forest and Environmental Science, University of Freiburg, Stühlingen (Švicarska)
- Kruse, F. A. and Hauff, P. L., 1991, Identification of illite polytype zoning in disseminated gold deposits using reflectance spectroscopy and X-ray diffraction -- Potential for mapping with imaging spectrometers: IEEE Transactions on Geoscience and Remote Sensing (TGARS), v. 29, no. 1, p. 101-104.
- Kruse, F. A., 1993, Imaging Spectroscopy: New directions for terrestrial geology: in Pieters, C. M., and Englert, A. J., (eds), Remote Geochemical Analysis: Elemental and Mineralogical Composition, Cambridge University Press, New York, NY, p. 283 - 307.

- Kumar V., Mohan A., Agarwal S., Saddiqui A., 2001., Evaluating the Close Range Hyperspectral Data for Feature Identification and Mapping, Indija
- Lucas R., Rowlands A., Neimann O., Merton R., 2004 Hyperspectral Sensors and Applications, Njemačka
- Manolakis D., Shaw G., 2002, Detection Algorithms for Hyperspectral Imaging Applications, IEEE Signal Processing Magazine, 29-43, Sjedinjene Američke Države
- Matsuki T., Naoto Y., 2015., Hyperspectral Tree Species Classification of Japanese Complex Mixed Forest With the Aid of Lidar Data, Japan
- Miljković V., 2017., Prostorna kalibracija multispektralnih i hiperspektralnih senzora u blizupredmetnoj fotogrametriji, Zagreb
- Murtha P.A., 1972. Remote Sensing and Vegetation Damage: A Theory for Detection and Assessment, Kanada
- Pernar, R., 1994: Način i pouzdanost određivanja oštećenosti hrasta lužnjaka (*Quercus robur*, L.) na infracrvenim kolornim (ICK) aerosnimkama. Glas. šum. pokuse, 31:1-34
- Santonu, G., M. Kuldeep, 2015: Development of a Web-based Vegetation Spectral Library (VSL) for Remote Sensing Research and Applications. PeerJ PrePrints, CC-BY 4.0 Open Access, <https://dx.doi.org/10.7287/peerj.preprints.915v1>, Sjedinjene Američke Države
- Smith R. B., 2012., Tutorial: Introduction to Hyperspectral Imaging, Sjedinjene Američke Države
- Rajedran, S., S. Aravindan, T. Jeyavel Rajakumar, R. Sivakumar, K. R. Murali Mohan, 2009: Hyperspectral Remote Sensing and Spectral Signature Applications. NIPA, Pitam Pura, 508 str., New Delhi, India
- Treitz P. M., Howarth P.J., 1999. Hyperspectral remote sensing for estimating biophysical parameters of forest ecosystems, Sjedinjene Američke Države
- Vane G., Green R.O., Chrien T. G., Enmark H. T., Hansen E. G., Wallace M. P., 1993. The airborne visible/infrared imaging spectrometer (AVIRIS), Sjedinjene Američke Države
- Veys C., Grieve, B., Hibbert J., Phillip D., 2017., An Ultra-Low-Cost Active Multispectral Crop Diagnostics Device, Ujedinjeno Kraljevstvo

Linkovi:

- http://image.absoluteastronomy.com/images/encyclopediainages/i/in/infrared_spectrum.gif
- http://plantphys.info/plant_physiology/light.shtml
- <https://sphereoptics.de/en/product/hyperspectral-line-scanners-0-4-%C2%B5m-2-5-%C2%B5m/>
- https://www.hyspex.no/hyperspectral_imaging/
- https://s3.amazonaws.com/content.satimagingcorp.com/media/cms_page_media/1414/spectra-7.png
- https://en.wikipedia.org/wiki/Hyperspectral_imaging
- https://www.nasa.gov/images/content/612114main_AVIRIS_checkout.jpg
- <https://www.findlight.net/blog/2017/05/21/hyperspectral-imaging/>
- https://www.mdpi.com/water/water-11-01368/article_deploy/html/images/water-11-01368-g004.png
- <https://www.techbriefs.com/component/content/article/tb/supplements/it/features/15361?start=1>